Docket No. 826.1628/JDH

IN THE UNITED STATES PATENT AND TRADEMARK OFFICE

In re Patent Application of:	)	
	)	
Jun IBUKI, et al.	)	
	)	Group Art Unit: Unassigned
Serial No.: To be assigned	)	
	)	Examiner: Unassigned
Filed: September 27, 2000	)	
	)	
For: FACT DATA UNIFYING METHOD AND APPARATUS	)	

SUBMISSION OF CERTIFIED COPY OF PRIOR FOREIGN APPLICATION IN ACCORDANCE WITH THE REQUIREMENTS OF 37 C.F.R. §1.55

Honorable Commissioner of
Patents and Trademarks
Washington, D.C. 2023l

Sir:

In accordance with the provisions of 37 C.F.R. §1.55, the applicants submit herewith a certified copy of the following foreign application:

Japanese Patent Application No. 11-310766, filed: November 1, 1999.

It is respectfully requested that the applicants be given the benefit of the foreign filing date as evidenced by the certified papers attached hereto, in accordance with the requirements of 35 U.S.C. §119.

Respectfully submitted,

STAAS & HALSEY LLP

Date: September 27, 2000 By: _____

James D. Halsey, Jr.
Registration No. 22,729

700 Eleventh Street, N.W., Suite 500
Washington, D.C. 20001
(202) 434-1500

PATENT OFFICE

JAPANESE GOVERNMENT

This is to certify that the annexed is a true copy of the following application as filed with this Office.

Date of Application: November 1, 1999

Application Number: Patent Application No. 11-310766

Applicant(s): FUJITSU LIMITED

July 21, 2000

Commissioner,

Patent Office Kozo Oikawa

Certificate No. 2000-3055953

日　本　国　特　許　庁
PATENT OFFICE
JAPANESE GOVERNMENT

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出願年月日
Date of Application: １９９９年１１月　１日

出願番号
Application Number: 平成１１年特許願第３１０７６６号

出願人
Applicant (s): 富士通株式会社

２０００年　７月２１日

特許庁長官
Commissioner,
Patent Office 及川耕造

出証番号　出証特２０００－３０５５９５３

【書類名】　特許願

【整理番号】　9951080

【提出日】　平成11年11月 1日

【あて先】　特許庁長官　殿

【国際特許分類】　G06F 17/20

【発明の名称】　事実データ統合方法および装置

【請求項の数】　11

【発明者】

【住所又は居所】　神奈川県川崎市中原区上小田中４丁目１番１号　富士通株式会社内

【氏名】　伊吹　潤

【発明者】

【住所又は居所】　神奈川県川崎市中原区上小田中４丁目１番１号　富士通株式会社内

【氏名】　落谷　亮

【発明者】

【住所又は居所】　神奈川県川崎市中原区上小田中４丁目１番１号　富士通株式会社内

【氏名】　西野　文人

【特許出願人】

【識別番号】　000005223

【氏名又は名称】　富士通株式会社

【代理人】

【識別番号】　100100930

【弁理士】

【氏名又は名称】　長澤　俊一郎

【電話番号】　03-3822-9271

【選任した代理人】

【識別番号】　100080894

【弁理士】

【氏名又は名称】　京谷　四郎

【電話番号】　03-3823-7935

【手数料の表示】

【予納台帳番号】　024143

【納付金額】　21,000円

【提出物件の目録】

【物件名】　明細書　1

【物件名】　図面　1

【物件名】　要約書　1

【包括委任状番号】　9704945

【プルーフの要否】　要

【書類名】　明細書

【発明の名称】　事実データ統合方法および装置

【特許請求の範囲】

【請求項１】　対象とする事物、属性名、属性値の３つ組によって規定される事実データをテキストから抽出し、

抽出された事実データについて同種のデータをまとめて、テキスト全体にわたるデータ集計を行ない、

集計されたデータ集合を走査して両立し得ない不整合データ群を検出し、

不整合データ群においてどれが正しいデータであるかを判断し、誤りデータを排除して正しい事実データの統合を行う

ことを特徴とする事実データ統合方法。

【請求項２】　対象とする事物、属性名、属性値の３つ組によって規定される事実データをテキストから抽出するデータ抽出部と、

データ抽出部で抽出された事実データについて、テキスト全体にわたり同種のデータをまとめ、生起回数を集計するデータ集計部と、

データ集計部において集計されたデータ集合を走査して両立し得ない不整合データ群を検出する不整合検出部と、

不整合検出部で検出された不整合データ群の中でどれが正しいデータであるかを判断する正誤判定部と、

データ集計部において集計された正しいデータ、および、正誤判定部において正しいデータと判断されたデータを集計する最終データ集積部とを備えた

ことを特徴とする事実データ統合装置。

【請求項３】　事実データをテキストから抽出する際にデータに信頼度を付与する信頼度付与部を設け、

データ集計部において生起回数を集計する際、集計されたデータの信頼度を個々のデータの信頼度から計算して集計結果に付与し、

正誤判定部において、上記データに付与された信頼度を利用してデータ群中の各データの正誤の判断を行なう

ことを特徴とする請求項２の事実データ統合装置。

【請求項４】　上記信頼度付与部が、テキストから事実データを抽出する際に抽出の対象となったテキストの持つイベント情報の種類を判定するイベント型抽出部と、

イベント型と信頼度の対応表に基づき、イベント型から信頼度を評価する信頼度評価部とを備えている

ことを特徴とする請求項３の事実データ統合装置。

【請求項５】　上記信頼度付与部が、テキスト中の抽出対象とする対象事物に対しての注目度を計算する注目度評価部と、

上記注目度に基づき、データの信頼度を評価する信頼度評価部とを備えている

ことを特徴とする請求項３の事実データ統合装置。

【請求項６】　上記信頼度付与部が、テキストの発行社、著者等の書誌情報と該テキストに記述される各データの信頼度を対応付ける書誌情報と信頼度の対応表と、

テキスト中からデータの抽出を行なう際、上記書誌情報と信頼度の対応表を参照して該テキストの書誌情報からテキストの信頼度を評価する信頼度評価部とを備えている

ことを特徴とする請求項３の事実データ統合装置。

【請求項７】　データ抽出部によって抽出する事実データに正誤フラグを付与し、正誤フラグを付加させた正誤のフラグつきの事実データを入力として受けとり、事実データの属性名毎に特定の属性値をとるデータの正誤の期待値を計算し、書誌情報と信頼度の対応表を生成する

ことを特徴とする請求項６の事実データ統合装置。

【請求項８】　対象事物、属性名と、正誤判定の際に利用する判定方法とを対応付けた属性・判定方法対応表と、

上記属性・判定方法対応表に基づき、属性名に応じた正誤判定方法を決定する判定方法決定部とを備え、

正誤判定部は、不整合データ群が入力された際、上記判定方法決定部により指定された判定方法を用いて正誤判定を行う

ことを特徴とする請求項２，３，４，５，６または請求項７の事実データ統合装

置。

【請求項９】　データ抽出部と不整合検出部の間に誤りパターン除去部を設け、

誤りパターン除去部は、データ抽出部で抽出された事実データと、予め登録された誤りパターンとを照合することにより個々のデータ毎に正誤の判断を行ない、抽出された事実データが予め登録された誤りパターンに合致した時に誤りと判断して棄却し、問題がないとされたデータのみを不整合検出部に送る

ことを特徴とする請求項２，３，４，５，６，７または請求項８の事実データ統合装置。

【請求項１０】　データ集計部の後にデータ統合部を設け、

データ統合部は、互いに似ているデータを統合して、一つのデータに統合した後に不整合検出部に渡す

ことを特徴とする請求項２，３，４，５，６，７または請求項８の事実データ統合装置。

【請求項１１】　テキストから抽出された対象事物、属性名、属性値の３つ組によって規定される事実データを統合するデータ統合プログラムを記録した記録媒体であって、

上記データ統合プログラムは、対象とする事物、属性名、属性値の３つ組によって規定される事実データをテキストから抽出し、

抽出された事実データについて同種のデータをまとめて、テキスト全体にわたるデータ集計を行ない、

集計されたデータ集合を走査して両立し得ない不整合データ群を検出し、

不整合データ群においてどれが正しいデータであるかを判断し、誤りデータを排除して正しい事実データの統合を行う

ことを特徴とするデータ統合プログラムを記録した記録媒体。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】

本発明は、文書中の事実の記述を抽出して整合性をもつデータの集合としてデ

ータベース化したり、また事実データの矛盾点から対応する元テキストの持つ誤りの検出や訂正をする事実データ統合方法および装置に関する。

【０００２】

【従来の技術】

テキスト中の情報の抽出技術としては従来から種々の方法が提案されており、例えば、新製品の情報、組織体情報等の予め決められた枠組に従ったデータの場合は、テキスト中の表現形式と抽出されるデータとの対応表を保持しておき、テキストを走査して規定された表現形式にマッチした時に対応するデータを取り出すことが行なわれている。

例えば、図２０（ａ）に示すような対応表を保持しておき、入力テキストを走査して、同図（ｂ）（ｃ）に示すように「対象事物」、「属性名」、「属性値」からなる事物データを抽出する。この例の場合には、入力テキストの「Ｃ社の新社長」、「Ｄ氏に決定した」がそれぞれ対応表の＊１，＊２にマッチするので、同図（ｄ）に示すように対象事物としては「Ｃ社」、属性名として「代表者」、属性値として「Ｄ氏」が抽出される。

一方、誤りの訂正技術に関しては、テキスト中に存在する表記レベルの誤りに対象を限った場合には様々な技術が既に存存している。例えば、テキスト中に存在する表現を登録しておき未登録語を指摘したり、表記の揺れの指摘などの方法が知られている。

【０００３】

【発明が解決しようとする課題】

上述のようにテキストからの事実データの抽出は広く行なわれているが、見たい情報がテキスト中の一箇所からの情報だけで得られるとは限らないので一般にはテキスト全体からのデータを統合することが必要となる。

ところが、テキスト自体の含む誤り、あるいは抽出処理の誤り等によって一般には抽出されるデータ中にかなりの誤り（あるいはデータの不統一）が存在し、これらを人手でチェックして除いたり、書き換える必要があるために単純に集計することができなかった。

本発明は上記した事情を考慮してなされたものであって、テキスト中の誤った

記述や抽出処理の誤りに起因する抽出データ中の誤りやバラツキの訂正や標準化を行うことにより、適切なデータの集積を可能とすることを目的とする。

【０００４】

【課題を解決するための手段】

図１は本発明の基本構成を示すブロック図である。同図において、１は対象とする事物、属性名、属性値の３つ組によって規定される事実データをテキストから抽出するデータ抽出部、２は同種のデータをまとめ、生起回数を集計するデータ集計部、３はデータ集計部において集計されたデータ集合を走査して両立し得ない不整合データ群を検出する不整合検出部、４は不整合データ群の中でどれが正しいデータであるかを判断する正誤判定部、５はデータ集計部において集計された正しいデータ、および、正誤判定部において正しいデータと判断されたデータを集計する最終データ集積部である。

また、６は事実データをテキストから抽出する際にデータに信頼度を付与する信頼度付与部、７は互いに似ているデータを統合して、一つのデータに統合するデータ統合部、８は予め登録された誤りパターンに合致した事実データを誤りとして棄却する誤りパターン除去部、９は正誤判定部における正誤判定方法を決定する判定方法決定部である。

【０００５】

図１に示すように本発明においては、次のようにして前記課題を解決する。

（１）対象とする事物、属性名、属性値の３つ組によって規定される事実データをテキストから抽出するデータ抽出部１と、データ抽出部１で抽出された事実データについて、テキスト全体にわたり同種のデータをまとめ、生起回数を集計するデータ集計部２と、データ集計部２において集計されたデータ集合を走査して両立し得ない不整合データ群を検出する不整合検出部３と、不整合検出部３で検出された不整合データ群の中でどれが正しいデータであるかを判断する正誤判定部４と、データ集計部２において集計された正しいデータ、および、正誤判定部において正しいデータと判断されたデータを集計する最終データ集積部５とを設け、抽出された事実データから誤りデータを排除して適切なデータの集積を可能とする。

（２）上記（１）において、事実データをテキストから抽出する際にデータに信頼度を付与する信頼度付与部６を設け、データ集計部２において生起回数を集計する際、集計されたデータの信頼度を個々のデータの信頼度から計算して集計結果に付与し、正誤判定部４において、上記データに付与された信頼度を利用してデータ群中の各データの正誤の判断を行なうことにより正誤判断の精度を高める。

（３）上記（２）において、上記信頼度付与部６を、テキストから事実データを抽出する際に抽出の対象となったテキストの持つイベント情報の種類を判定するイベント型抽出部と、イベント型と信頼度の対応表に基づき、イベント型から信頼度を評価する信頼度評価部とから構成し、正確な信頼度を付与する。

（４）上記（２）において、上記信頼度付与部６を、テキスト中の抽出対象とする対象事物に対しての注目度を計算する注目度評価部と、上記注目度に基づき、データの信頼度を評価する信頼度評価部とから構成し、正確な信頼度を付与する。

（５）上記（２）において、上記信頼度付与部６を、テキストの発行社、著者等の書誌情報と該テキストに記述される各データの信頼度を対応付ける書誌情報と信頼度の対応表と、テキスト中からデータの抽出を行なう際、上記書誌情報と信頼度の対応表を参照して該テキストの書誌情報からテキストの信頼度を評価する信頼度評価部とから構成し、作者、発行社等による一般的な傾向を考慮した信頼度を付与する。

（６）上記（５）において、データ抽出部１によって抽出する事実データに正誤フラグを付与し、正誤フラグを付加させた正誤のフラグつきの事実データを入力し、事実データの属性名毎に特定の属性値をとるデータの正誤の期待値を計算し、書誌情報と信頼度の対応表を生成することにより、属性値と信頼度の対応表を半自動的にテキストから生成する。

（７）上記（１）～（６）において、対象事物、属性名と、正誤判定の際に利用する判定方法とを対応付けた属性・判定方法対応表と、上記属性・判定方法対応表に基づき、属性名に応じた正誤判定方法を決定する判定方法決定部とを設け、不整合データ群が入力された際、上記判定方法決定部により指定された判定方法

を用いて正誤判定部により正誤判定を行うことにより、属性に応じた柔軟な正誤判断を行なう。

（８）上記（１）～（７）において、データ抽出部１と不整合検出部の間に誤りパターン除去部を設け、誤りパターン除去部８において、データ抽出部１で抽出された事実データと、予め登録された誤りパターンとを照合することにより個々のデータ毎に正誤の判断を行ない、抽出された事実データが予め登録された誤りパターンに合致した時に誤りと判断して棄却し、問題がないとされたデータのみを不整合検出部に送ることにより、単独で判断可能な誤りの除去を行なう。

（９）上記（１）～（６）において、データ集計部２の後にデータ統合部７を設け、データ統合部７において、互いに似ているデータを統合して、一つのデータに統合した後に不整合検出部３に渡すことにより、同じ事物の異なる表現による揺らぎを吸収する。

【０００６】

【発明の実施の形態】

以下本発明の実施の形態について説明する。

図２は本発明の事実データ統合処理を行うためのシステムの構成例を示す図である。同図において、１０１はＣＲＴ、液晶ディスプレイ等の表示装置、キーボード、マウス等の、文字、記号、命令等を入力するための入力装置から構成される入出力装置、１０２はＣＰＵ、１０３はＲＯＭ、ＲＡＭ等から構成されるメモリ、１０４はプログラム、データ等を記憶する外部記憶装置、１０５はフロッピィディスク、ＭＯ、ＣＤ－ＲＯＭ等の可搬型記憶媒体にアクセスしてデータの読み出し／書き込みを行う媒体読み取り装置、１０６は電話回線を使用してデータ通信をするためのモデム、ＬＡＮ等のネットワークを使用してデータ通信を行うためのネットワークカード等を含む通信インタフェースである。

外部記憶装置１０４には本発明の事実データ統合処理を行うプログラム、事実データを抽出するテキストデータが格納されており、また、事実データ統合処理を行った結果得られた統合データ等が格納される。

【０００７】

図３は本発明の第１の実施例の機能ブロック図であり、同図により本発明の第

１の実施例について説明する。

図３において、１１はテキスト中の事実データに関する記述を解析し、事実データとして抽出するデータ抽出部、１２はデータ抽出部１１において抽出された事実データの内、同じデータを一つにまとめて各事実データの生起回数を計数するデータ集計部、１３はデータ不整合検出部であり、テキスト中から抽出された事実データ集合中における不整合（例えば、両立できないような事実データの組み合わせ）を捜し出す。１４はデータ不整合検出部１３で検出された不整合データのどれが正しくどれが誤っているかを判断する正誤判定部、１５は正しいと検証されたデータを集積して提示する最終データ集積部である。

【０００８】

図３において、テキストデータが入力されると、データ抽出部１２では、前記従来例で説明したように、テキスト中の記述を解析し、事実データとして抽出する。

図４（ａ）は、前記図２０（ａ）に示した対応表を用い、テキスト中から該対応表に規定された表現形式の事実データを抽出した場合におけるデータ抽出部１２の出力例であり、前記した対応表によれば図４（ａ）に示すように対象事物（Ａ社、Ｆ社、…、Ｈ社）、属性名（代表者、…、所在）、属性値（Ｂ、Ｇ、…、Ｃ国）からなる事実データが抽出される。

データ集計部１２では、上記事実データをソートして同じデータをまとめ、各事実データの生起回数を計数する。図４（ｂ）は同図（ａ）に示した事実データについてのデータ集計部１２の出力例を示す図であり、同図に示すように「対象事物」、「属性名」、「属性値」と、それらが一致する事実データの生起回数が出力される。

【０００９】

不整合検出部１３は、事実データ集合中での不整合データを検出する。そのため例えば次のような処理を行う。

i)　データ集合中で全ての対象事物に対して以下の操作を繰り返す。

ii)選択した対象事物のもつ全ての属性名について以下の操作を繰り返す。

iii)同じ属性名に対応する属性値が複数存在すれば、そのデータ群を不整合デ

ータ群として出力し、それ以外は整合データとして出力する。

【００１０】

図４（ｃ）は不整合検出部１３において不整合データとして検出された不整合データ例を示す図であり、同図に示すようにデータ集計部１２で集計された事実データの内、対象事物「Ａ社」、属性名「代表」について、Ｂ氏とＤ氏の２種類の値があるので、属性値「Ｂ」と「Ｄ」が不整合データとして検出され正誤判定部１４に送られる。また、データ集計部１２で集計された残りのデータは、整合データとして最終データ集積部１５に送られる。

正誤判定部１４では不整合データについてどれが正しくどれが誤っているかを判断する。

これについては次のように様々なアルゴリズムが考えられる。

i)群中の最大生起回数をもつデータを正しいと判断し、他を誤りとする。

ii）特定の閾値以上の生起回数をもつデータを正しいと判断し他を誤りとする。

【００１１】

図４（ｄ）は正誤判定部１４の出力例を示す図であり、同図は図４（ｃ）の不整合データについて、上記i)のアルゴリズムにより正誤判定をした場合の出力例を示している。

不整合データとして検出された対象事物「Ａ社」、属性名「代表」の属性値「Ｂ」、「Ｄ」の内、属性値「Ｂ」の生起回数が２件、「Ｄ」の生起回数が１件であるので、この例では、図４（ｄ）に示すように属性値「Ｂ」が「正」として採用され、属性値「Ｄ」が誤りとして棄却される。

【００１２】

最終データ集積部１５では、上記不整合検出部１３から整合データとして送られてきたデータおよび正誤判定部１４で正しいデータとして判定されたデータを集積して提示する。図４（ｅ）は最終データ集積部１５の出力例を示す図であり、同図に示すように、データ集計部１２で集計されたデータの内、不整合データ検出部１３から整合データとして送られてきたデータおよび正誤判定部１４で正しいとして判定されたデータが正しいデータとして出力される。

【００１３】

図５は本実施例の処理を示すフローチャートであり、同図により上記処理を説明する。

図５において、ステップＳ１において、入力されたテキストデータの事実データに関する記述を解析して事実データとして抽出し、例えば前記図４（ａ）に示したような事実データを得る。

ステップＳ２において、抽出された事実データを対象事物、属性名、属性値についてソートし、ソートしたデータをカウントする。その結果、前記図４（ｂ）の示したデータが得られる。

【００１４】

ステップＳ３において、ソートされた対象事物を一つ取り出す。ステップＳ４において、取り出した対象事物のなかの一つの属性名を選択し、ステップＳ５においてその整合性をチェックする。そして、例えば前記図４（ｃ）に示したような不整合データが検出された場合には、ステップＳ６に行き、前記①，②に示したアルゴリズムにより不整合データの正誤判定を行い、誤ったデータを棄却する。また、データが整合している場合には、ステップＳ７において、整合データを集積する。

ステップＳ８において、属性名についての整合性チェックが尽くされたかを判定し、尽くされていない場合には、ステップＳ４に戻り上記処理を繰り返す。また、属性名の整合性チェックが尽くされた場合には、ステップＳ９において、対象事物についての整合性チェックが尽くされたかを判定し、尽くされていない場合には、ステップＳ３に戻り上記処理を繰り返す。また、対象事物についての整合性チェックが尽くされた場合には処理を終了する。

【００１５】

図６は本発明の第２の実施例の機能ブロック図であり、本実施例は、第１の実施例において、信頼度付与部を設け、テキストデータの信頼度を付与し信頼度に基づき正誤判断を行うようにしたものである。

同図において、データ抽出部１１は前記したように、テキスト中の事実データに関する記述を解析し、データとして抽出する。また、信頼度付与部１６はデータ抽出の対象となるテキストのもつ情報を利用して抽出したデータの信頼度の評

価を行う。

【００１６】

具体的な評価方法としては例えば次のような手法を用いることができる。

①イベント型による信頼度の評価

部分テキストからイベント型を抽出しこれにより部分テキストの信頼度を評価する。

②注目度による信頼度の評価

対象事物のテキスト中における注目度に着目し、信頼度の評価を行う。

③書誌情報による信頼度の評価

テキストのもつ書誌情報（著者、発行媒体等）によって信頼度を評価する。例えば、テキストが新聞記事の場合にはその新聞が一般紙か、スポーツ紙か等のニュースソースによって信頼度を評価する。

【００１７】

次に、データ集計部１２では信頼度付のデータのデータ集計を行なうため、個々の信頼度からデータ集計としての信頼度を計算する。

このアルゴリズムとしては次のようなものが考えられる。

i)個々のデータの信頼度の内で最大のものをデータ集計の信頼度とする。

ii）個々のデータの信頼度の平均をデータ集計の信頼度とする。

正誤判断部１５においてはデータ集計のもつ信頼度、生起回数を元にしてどのデータが正しいかの判断を行なう。このアルゴリズムとしては次のようなものが考えられる。

i)個々のデータの信頼度の内で最大のものを正しいとし残りを全て誤りとする。

ii）信頼度の閾値を定め、特定の値以上の信頼度をもつデータを正しいとする。

【００１８】

図７は図６に示した信頼度付与部１６の第１の内部構成例を示す図であり、この例は上記①のイベント型により信頼度を評価する場合の構成を示している。

図７において、１１は前記したテキストから事物データを抽出するデータ抽出部であり、データ抽出部１１は前述したようにテキスト中の事実データに関する記述を解析し、データとして抽出する。例えば、原文が図８（ａ）に示すように

「Ａ社の代表に…」、「Ａ社のＤ社長が…」、「Ａ社はＢを…」の場合、同図に示すように「対象事物」として、「Ａ社」、「属性名」として「代表」、「製品」、「属性値」として「Ｂ氏」、「Ｄ社長」、「Ｂ」が抽出される。

【００１９】

１６は信頼度付与部であり、信頼度付与部１６におけるイベント型抽出部１６ａは原文から図８（ｂ）に示すようなキーワード群を抽出し、図８（ｃ）に示すキーワード・イベント対応表１６ｃを参照して、テキスト中に存在するキーワードが表中の値とマッチした場合に対応するイベント型をもつと判断する。その結果、図９（ｅ）に示すように抽出対象となった部分テキストからイベント型が抽出される。

信頼度評価部１６ｂでは図８（ｄ）に示すイベント型・信頼度対応表１６ｄを参照して、図９（ｆ）に示すようにイベント型により、事実データのもつべき信頼度を評価する。また、イベント型に対応しないものは、default として信頼度を例えば０．５とする。

以上のようにして信頼度を付与することにより、例えば死亡記事は特に人物データに入念なチェックがかかるため人事異動等に関する記事より信頼度が高いなどの知識を利用して、正確な信頼度の評価を行うことができる。

【００２０】

図１０は上記信頼度付与部の第２の内部構成例を示す図であり、この例は前記②の注目度により信頼度を評価する場合の構成を示している。

図１０において、１１は前記したように事物データ自体の抽出を行なう事物データ抽出部、１６は信頼度付与部であり、１６ｅは抽出対象となった事物のテキスト中における注目度の評価を行なう注目度評価部、１６ｆは注目度により信頼度を評価する信頼度評価部である。

【００２１】

注目度評価部１６ｅにおける注目度の評価手法としては、次のようなアルゴリズムが考えられる。

i)対象事物の直後につく助詞を調べ、かかり助詞「は」、「も」等がついた事物の注目度を最も高い値とし、それ以外の場合注目度を低い値とする。

例えば、図１１（ａ）に示すように、注目度を上記かかり助詞がついた主語は０．８、目的語は０．５、その他の要素は０．４のように定め、図１１（ｂ）に示すように、原文中の事物データが上記主語であるか、目的語であるか、その他の要素であるかを判定し、それに応じて注目度を設定する。

ii）対象事物のテキスト中の位置（先頭から何番目の単語であるか）を数え、それを位置と注目度の対応表を利用して注目度を評価する。

例えば、図１１（ｃ）に示すように、単語の位置と注目度の対応表を用い、原文中の事物データの位置に応じて、注目度を設定する。

信頼度評価部１６ｆは、上記のようにして抽出された注目度を利用して、事実データの持つべき信頼度を計算する。基本的には、注目度の高い事物に対する信頼度が上がるように評価アルゴリズムを設定する。例えば、図１１（ｄ）に示すように、注目度が閾値αより大きいか否かを調べ、それに応じて信頼度を付与する。

以上のように、係り助詞や対象事物のテキスト中の位置等の情報を利用して注目されている事物の信頼度を上げることにより正確な正誤の判断ができる。

【００２２】

図１２は上記信頼度付与部の第３の内部構成例を示す図であり、この例は前記③の書誌情報により信頼度を評価する場合の構成を示している。

図１２において、１１は前記したように事物データ自体の抽出を行なうデータ抽出部、１６は信頼度付与部であり、信頼度付与部１６の信頼度評価部１６ｇは、テキストの持つ書誌情報（発行元、著者等）を入力として受け、書誌情報・信頼度の対応表１６ｈを利用して事実データのもつべき信頼度を調べる。

例えば、テキストの信頼度を発行元により評価し、信頼性の高い発行元であるか否かにより対応した信頼度を付与する。

【００２３】

以下、図１３の具体例により説明する。例えば、図１３（ａ）に示すように原テキストの記述に対応した書誌情報（発行元）がそれぞれ「Ａ新聞社」、「Ｂ新聞社」、「Ｃ通信社」であり、書誌情報・信頼度の対応表１６ｈが例えば図１３（ｂ）に示すように「Ａ新聞社」、「Ｂ新聞社」、「Ｃ通信社」についてそれぞ

れ信頼度が０．６、０．８、０．９として設定されている場合、信頼度付与部１６は上記書誌情報・信頼度の対応表１６ｈにより各テキストに信頼度を付与し、データ抽出部１１から出力される事物データには、図１３（ｃ）に示すようにそのニュースソースに応じた信頼度が付与される。

【００２４】

前記図２に示したデータ集計部１２では前記したi)またはii）のアルゴリズムにより上記信頼度付き事実データを集計し、不整合検出部１３に渡す。不整合検出部１３では、図１３（ｃ）の事実データの内、Ａ社の代表が「Ｂ」と「Ｄ」で不整合であるので、図１３（ｄ）に示すように上記Ａ社の代表の「Ｂ」と「Ｄ」を不整合データとして、信頼度を付して正誤判定部１４へ出力する。

正誤判定部１４では、例えば前記i)またはii）のアルゴリズムを用いて、正誤判定を行う。例えば、前記i)の「群内で信頼度の最も高いものを正として選択し、他のデータを誤りとする」を用いて正誤判定を行う場合には、図１３（ｅ）に示すようにＡ社の代表の「Ｂ」を誤りとして棄却し、「Ｄ」を正としてデータ集積部１５へ出力する。その結果、データ集積部１５からは図１３（ｆ）に示すデータが出力される。

【００２５】

図１４は、図１２に示した信頼度付与部における書誌情報・信頼度の対応表１６ｈを生成するための構成例を示している。

図１４において、書誌情報属性走査部１７には正誤のフラグ付きの事実データが入力される。正誤のフラグは、事実データが正しいか否かを示すフラグであり、例えば人手で予め付与しておいたりあるいは他のシステムで自動的に付与するようにしてもよい。

書誌情報属性走査部１７は書誌情報等の各属性の値毎にデータ全体を探索し、その属性の持つ事実データを抽出する。例えば、前記した「Ａ新聞社」、「Ｂ新聞社」、「Ｃ通信社」、…等のニュースソースについての信頼度を得る場合には、上記新聞社、通信社毎にデータ全体を探索し、正誤フラグが付されている事実データを抽出する。

【００２６】

信頼度評価部１８は、上記書誌情報属性走査部１７において抽出された事実データについて、正誤フラグを元にデータの正解率を計算し、各書誌情報毎の信頼度を得る。これにより、例えば、上記した「Ａ新聞社」、「Ｂ新聞社」、「Ｃ通信社」、…のそれぞれの信頼度を得ることができる。

データ登録部１９は上記信頼度評価部１８において求めた信頼度を書誌情報・信頼度の対応表１６ｈに登録し、データベース化する。

上記のようにして書誌情報・信頼度の対応表１６ｈを生成することにより、人手で対応表へデータを登録する手間を省くことができる。

【００２７】

図１５は本発明の第３の実施例を示す図であり、本実施例は、前記図３、図６において、判定方法決定部２０を設けて、正誤判定部１５における判定方法を決定するようにしたものであり、その他の構成は前記図３、図６と同じである。

図１５において、不整合検出部１４に不整合データ群が入力されるとまず判定方法決定部２０において、事実データの対象事物、属性名を調べる。ついで、判定方法決定部２０は、属性・判定方法対応表２１を参照し、正誤判断のための方法を決定する。属性・判定方法対応表２１は、対象事物、属性名とそれに応じた判定方法が予め登録されている。

【００２８】

例えば、属性・判定方法対応表２１には、属性名が「部長」のように該当する人間が複数いる可能性のある場合には、「一定の閾値以上の信頼度をもつデータは全て正しいとする」というような第１の判定方法が登録され、また、属性名が「社長」のように１人しかいない場合には、「信頼度が最も高いデータのみを正しいとする」というような第２の判定方法が登録されており、判定方法決定部２０は、属性名が「部長」の場合には上記第１の判定方法を指定し、属性名が「社長」の場合には上記第２の判定方法を指定する。

正誤判定部１５は判定方法決定部２０において指定された正誤判定方法によりデータ群内の各データの正誤の判定を行う。

以上のようにして正誤判定を行うことにより、会社の部長のように複数の値をもつことが可能なデータと社長のようにユニークな値をもつことしか許されない

データに対して独自の正誤判断をすることが可能となる。

【００２９】

図１６は、本発明の第４の実施例を示す図であり、本実施例は、前記第１、第２の実施例において、誤りパターン除去部２２を設け単独のデータとして誤りであると判断されるデータを棄却するようにしたものであり、その他の構成は前記図３、図６と同じである。

図１６において、データ集計部１２と不整合検出部１３の間に誤りパターン除去部２２が設けられており、誤りパターン除去部２２は、データ集計部１２からデータが与えられたとき、誤りパターンデータベース２３を参照して、単独のデータとして誤りであると判断されるデータを棄却する。

【００３０】

図１７は図１６に示した誤りパターン除去部２２における誤りパターンの判断例を示す図である。この例では、電話番号における誤りパターンとして、頭が０でない数字が来るものを規定して誤りを検出する例を示している。

例えば、データ抽出部１１により抽出されたデータが図１７（ａ）に示すようにＡ社とＢ社の電話番号である場合、誤りパターン除去部２２では、誤りパターンデータベース２３を参照し、電話番号についての誤りパターンと比較する。

ここでは、誤りパターンデータベース２３に図１７（ｂ）に示す誤りパターンが登録されていたとする。ここで、図１７（ｂ）は０で始まらない電話番号は誤りであることを正規表現で表記したものである。

誤りパターン除去部２２で図１７（ａ）に示す電話番号と、図１７（ｂ）に示す誤りパターンを比較すると、Ｂ社の電話番号「１１９－０００３」は０以外の数字で始まっているので、誤りであると判定され、図１７（ｃ）に示すようにＢ社の電話番号が棄却される。

【００３１】

図１８は本発明の第５の実施例を示す図であり、本実施例はデータ統合部を設け、類似の属性値を持つデータの統合を行なうことにより、表記の揺れに対処するようにしたものであり、その他の構成は前記図６と同じである。

図１８において、データ集計部１２と不整合検出部１３の間にデータ統合部２

４が設けられており、データ統合部２４は、データ揺れデータベース２５を参照して類似の属性値を持つデータの統合を行なう。これにより、表記の揺れによって実際には大量に生起しているのに各表記に対してはあまり多くの生起例がないように見られ正誤の判断を誤る場合に対処することができる。

【００３２】

図１９は本実施例の処理例である。データ抽出部１１において図１９（ａ）に示すようなデータが抽出されると、データ統合部２４では、類似の値を持つデータの統合を行なう。

この例ではデータ揺れデータベース２５に、人名データの統合条件として「姓名が示された人名と、姓のみの人名は類似データとして統合可能」という条件が設定されているとする。データ統合部２４は、データ揺れデータベース２５を参照して上記条件により、Ａ社の属性名「代表」の属性値として「山田一郎」をもつデータと「山田」をもつデータを統合する。その結果図１９（ｂ）に示すようにＡ社の属性名「代表」のデータが統合され、データの頻度は両者の件数の和とされる。

【００３３】

データ統合部２４において上記のようにデータの統合が行われると、正誤判定部１４での正誤判定においては、上記統合された頻度により正誤判定を行う。例えば、前記した「群中の最大生起回数をもつデータを正しいと判断し、他を誤りとする」というアルゴリズムに正誤判定を行う場合には、図１９（ｃ）に示すようにＡ社の「代表者」について「山田太郎」が正とされ、「鈴木太郎」が誤りとされる。

この例の場合、「山田一郎」、「山田」のそれぞれの生起回数より「鈴木太郎」の生起回数の方が多いのでデータ統合を行わない場合には、「鈴木太郎」が正とされることとなるが、上記のようなデータ統合を行うことにより、正しい正誤の判断を行なうことが可能となる。

【００３４】

【発明の効果】

以上説明したように、本発明においては、以下の効果を得ることができる。

（１）事実データをテキストから抽出し、抽出された事実データについて同種のデータをまとめて、テキスト全体にわたるデータ集計を行ない、集計されたデータ集合を走査して両立し得ない不整合データ群を検出し、不整合データ群においてどれが正しいデータであるかを判断し、誤りデータを排除して正しい事実データの統合を行うようにしたので、テキスト中の誤った記述や抽出処理の誤りに起因する抽出データ中の誤りやバラツキに対して、誤り部分を排除して、適切なデータの集積を行なうことができる。

（２）事実データをテキストから抽出する際にデータに信頼度を付与し、信頼度を利用してデータ群中の各データの正誤の判断を行なうことにより正誤判断の精度を高めることができる。

（３）属性名に応じて正誤判定の際に使用する判定方法を指定し、該判定方法により正誤判定を行うことにより、属性に応じた柔軟な正誤判断を行なうことができる。

（４）抽出した事実データと予め登録された誤りパターンとを照合し、抽出された事実データが予め登録された誤りパターンに合致した時に誤りと判断して棄却することにより、単独で判断可能な誤りの除去を行なうことができる。

（５）互いに似ているデータを統合して、一つのデータに統合した後に不整合検出を行うことにより、同じ事物の異なる表現による揺らぎを吸収することができる。

【図面の簡単な説明】

【図１】

本発明の基本構成を示すブロック図である。

【図２】

事実データ統合処理を行うためのシステムの構成例を示す図である。

【図３】

本発明の第１の実施例を示す図である。

【図４】

第１の実施例の処理例を示す図である。

【図５】

本発明の第１の実施例の処理を示すフローチャートである。

【図６】

本発明の第２の実施例の機能ブロック図である。

【図７】

信頼度付与部の第１の内部構成例を示す図である。

【図８】

図７に示す信頼度付与部における処理例（１）を示す図である。

【図９】

図７に示す信頼度付与部における処理例（２）を示す図である。

【図１０】

信頼度付与部の第２の内部構成例を示す図である。

【図１１】

図１０に示す信頼度付与部における処理例を示す図である。

【図１２】

信頼度付与部の第３の内部構成例を示す図である。

【図１３】

図１２に示す信頼度付与部における処理例を示す図である。

【図１４】

書誌情報・信頼度の対応表を生成するための構成例を示す図である。

【図１５】

本発明の第３の実施例を示す図である。

【図１６】

本発明の第４の実施例を示す図である。

【図１７】

第４の実施例における誤りパターンの判断例を示す図である。

【図１８】

本発明の第５の実施例を示す図である。

【図１９】

第５の実施例の処理例を示す図である。

【図２０】

テキスト中の情報の抽出方法を説明する図である。

【符号の説明】

１，１１　データ抽出部

２，１２　データ集計部

３，１３　不整合検出部

４，１４　正誤判定部

５，１５　最終データ集積部

６，１６　信頼度付与部

７　データ統合部

８　誤りパターン除去部

９　判定方法決定部

１７　書誌情報属性走査部

１８　信頼度評価部

１９　データ登録部

２０　判定方法決定部

２１　属性・判定方法対応表

２２　誤りパターン除去部

２３　誤りパターンデータベース

２４　データ統合部

２５　データ揺れデータベース

【書類名】　　図面

【図１】

本発明の基本構成を示すブロック図

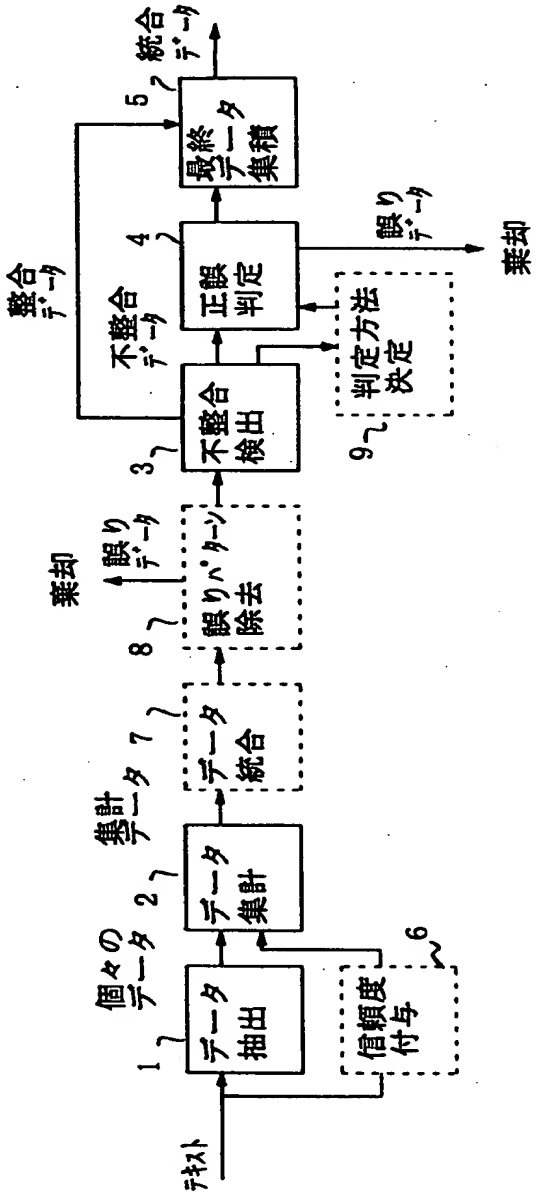

【図２】

本発明の実施例の処理を行うためのシステムの構成例を示す図

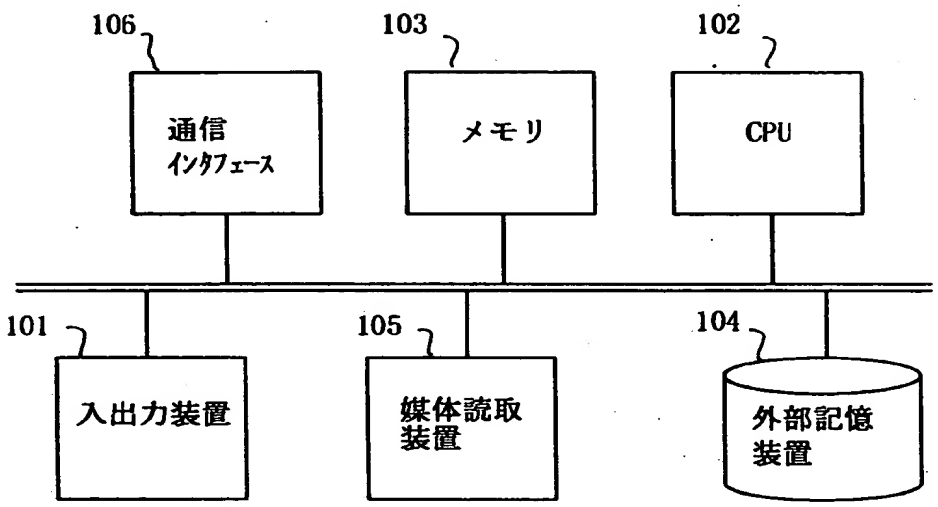

【図３】

本発明の第1の実施例を示す図

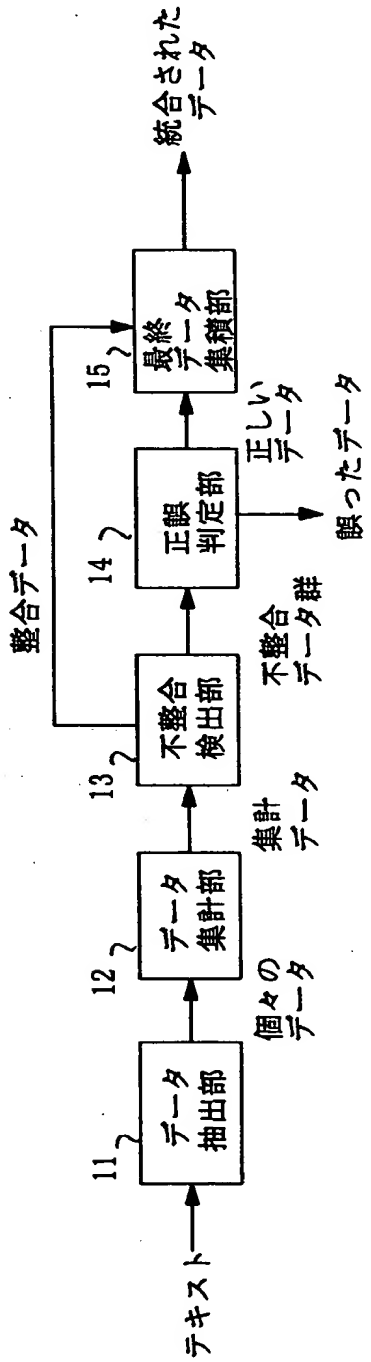

【図４】

第１の実施例の処理例を示す図

（ａ）データ抽出部の出力例

対象事物	属性名	属性値
A社	代表	B
F社	代表	G
A社	代表	B
A社	代表	D
H社	所在	C国

（ｂ）データ集計部の出力例

対象事物	属性名	属性値	生起回数
A社	代表	B	2
F社	代表	G	1
A社	代表	D	1
H社	所在	C国	1

（ｃ）不整合検出部の出力例

対象事物	属性名	属性値	生起回数
A社	代表	B	2
A社	代表	D	1

（ｄ）正誤判定部の出力例

データ			正誤フラグ
A社	代表	B	正
A社	代表	D	誤 →棄却

（ｅ）最終データ集積部の出力例

対象事物	属性名	属性値
A社	代表	B
F社	代表	G
H社	所在	C国

【図５】

本発明の第１の実施例の処理を示すフローチャート

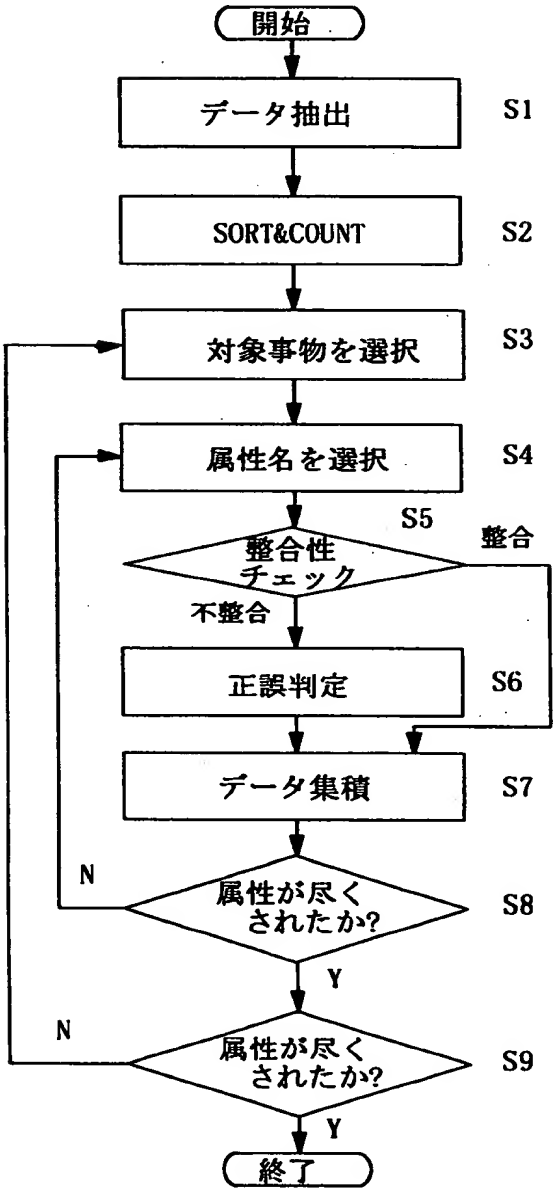

【図６】

本発明の第２の実施例の機能ブロック図

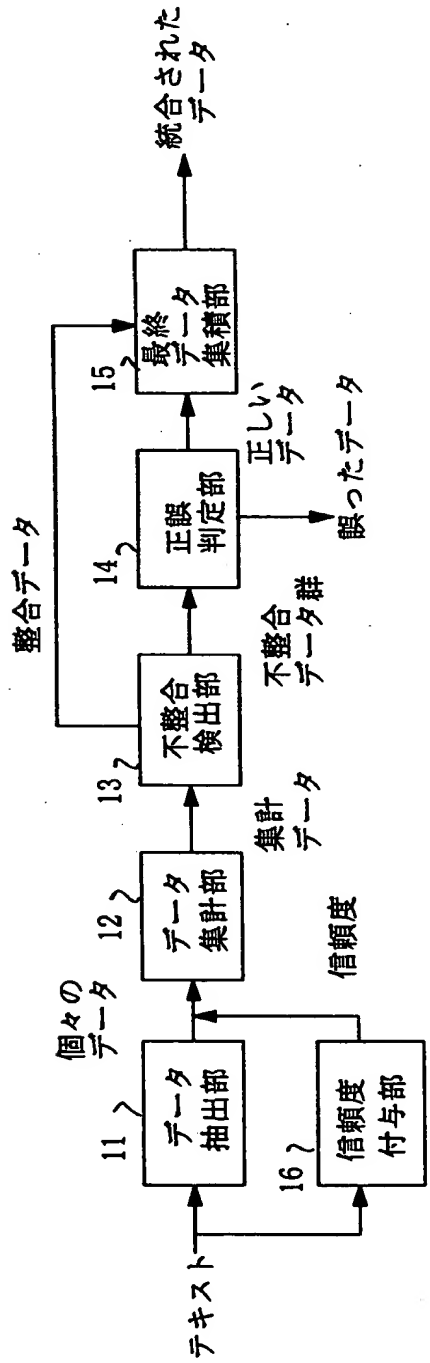

【図７】

信頼度付与部の第1の内部構成例を示す図

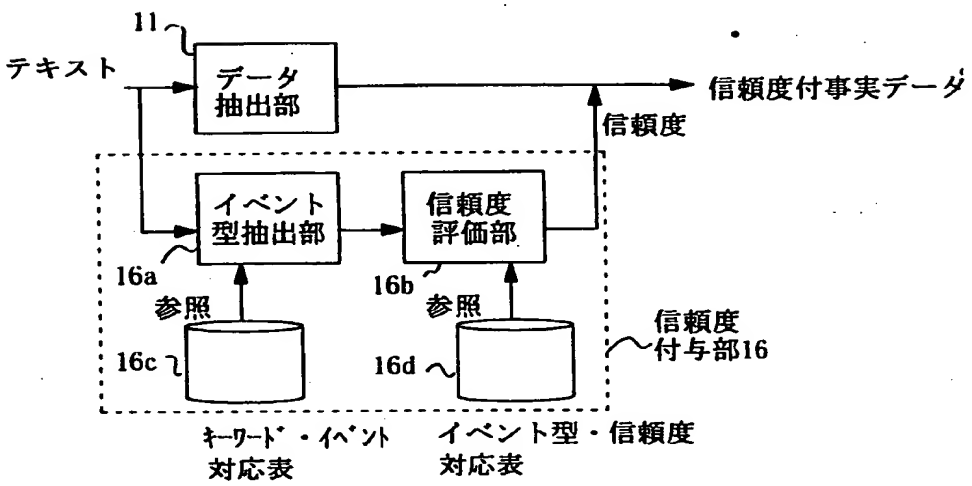

【図８】

図７に示す信頼度付与部における処理例（１）を示す図

（ａ）原文と抽出データ例

原文	対象事物	属性名	属性値
A社の代表にB氏が就任	A社	代表	B氏
A社のD社長が逝去	A社	代表	D社長
A社はBを発売	A社	製品	B

（ｂ）原文とキーワードの対応例

原文	抽出されたキーワード
A社の代表にB氏が就任	A社，A社，B氏，就任
A社のD社長が逝去	A社，D社長，逝去
A社はBを発売	A社，B，発売

（ｃ）キーワード、イベント型対応表例

キーワード	イベント型	信頼度
就任、解任	人事移動	０．８
死去	死亡記事	０．９

（ｄ）イベント型・信頼度対応表例

イベント型	信頼度
人事移動	０．８
死亡記事	０．９
default	０．５

【図９】

図７に示す信頼度付与部における処理例（２）を示す図

（ｅ）テキストのイベント型判断例

原文	抽出されたキーワード	イベント型
A社の代表にB氏が就任	A社、代表、B氏、就任	人事移動
A社のD社長が逝去	A社，D社長，逝去	死亡記事
A社はBを発売	A社，B，発売	default

（ｆ）各データに付与された信頼度例

原文	イベント型	信頼度
A社の代表にB氏が就任	人事移動	０．８
A社のD社長が逝去	死亡記事	０．９
A社はBを発売	default	０．５

【図１０】

信頼度付与部の第2の内部構成例を示す図

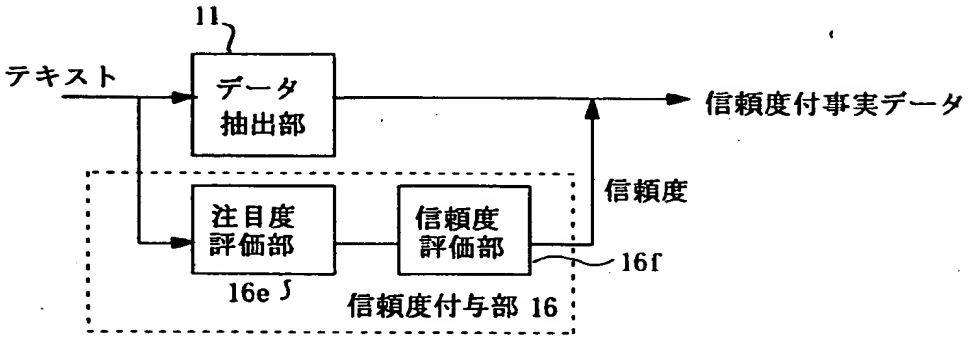

【図１１】

図１０に示す信頼度付与部における処理例を示す図

（ａ）注目度の評価方法の例

主語	０．８
目的語	０．５
その他の要素	０．４

（ｂ）原文中の事物に付与された注目度の例
（主語、目的語の順で注目度が高いとして
注目度を設定する例）

原文　A社のB社長は新製品群を発表
⇩　⇩　⇩
注目度　０．４　０．８　０．５

原文　A大臣はB社長と懇談
⇩　⇩
注目度　０．８　０．４

（ｃ）単語の位置と注目度対応表例

位置＜５	注目度＝　５－位置
位置＝＞　５	注目度　＝　０

（ｄ）信頼度評価アルゴリズム例

注目度　＞α	信頼度＝　０．９
注目度　≦α	信頼度＝　０．７

【図１２】

信頼度付与部の第３の内部構成例を示す図

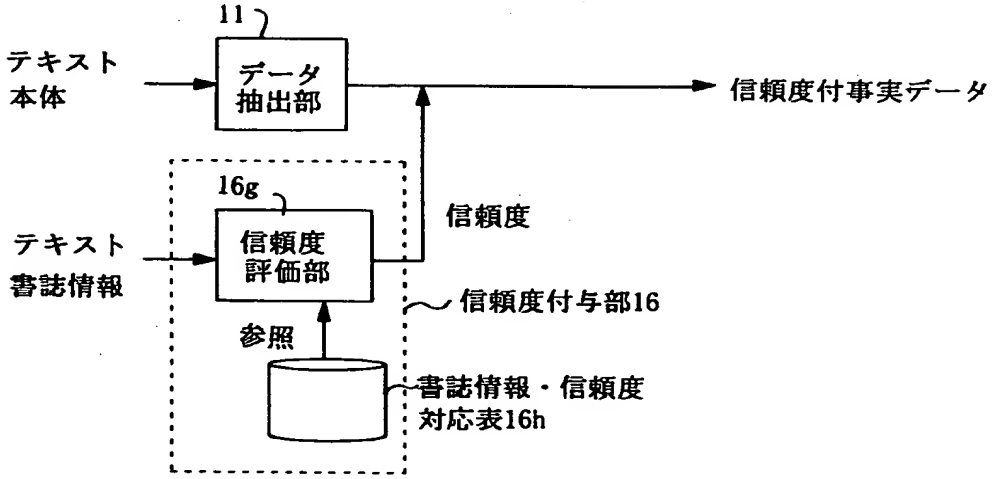

【図１３】

図１２に示す信頼度付与部における処理例を示す図

（ａ）原テキスト中の記述と書誌情報の例

テキスト	媒体
A社のB社長は…	A新聞社
A社（代表者D）	B新聞社
A社（本社：C県E市）	C通信社

（ｂ）書誌情報と信頼性の対応表の例

媒体名	信頼度
A新聞社	０．６
B新聞社	０．８
C通信社	０．９

（ｃ）データ抽出部の出力例

対象事物	属性名	属性値	信頼度
A社	代表	B	０．６
A社	代表	D	０．８
H社	所在	C国	０．９

（ｄ）不整合検出部の出力例

対象事物	属性名	属性値	信頼度
A社	代表	B	０．６
A社	代表	D	０．８

（ｅ）正誤判定部の判断例

対象事物	属性名	属性値	信頼度	正誤
A社	代表	B	０．６	誤
A社	代表	D	０．８	正

（ｆ）データ集積部の出力例

対象事物	属性名	属性値
A社	代表	B

【図１４】

書誌情報・信頼度の対応表を生成するための構成例を示す図

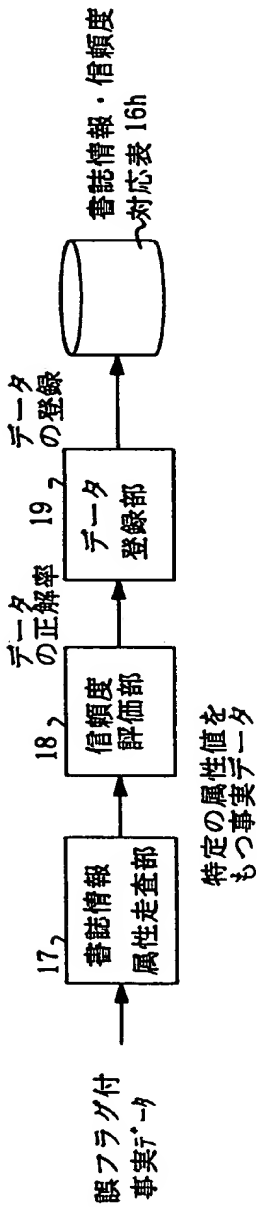

【図１５】

本発明の第３の実施例を示す図

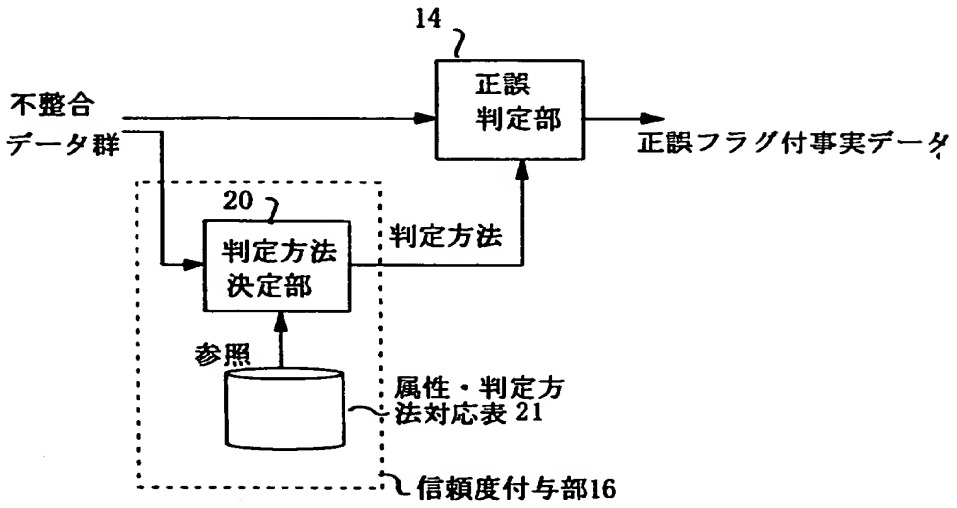

出証特２０００－３０５５９５３

【図１６】

本発明の第４の実施例を示す図

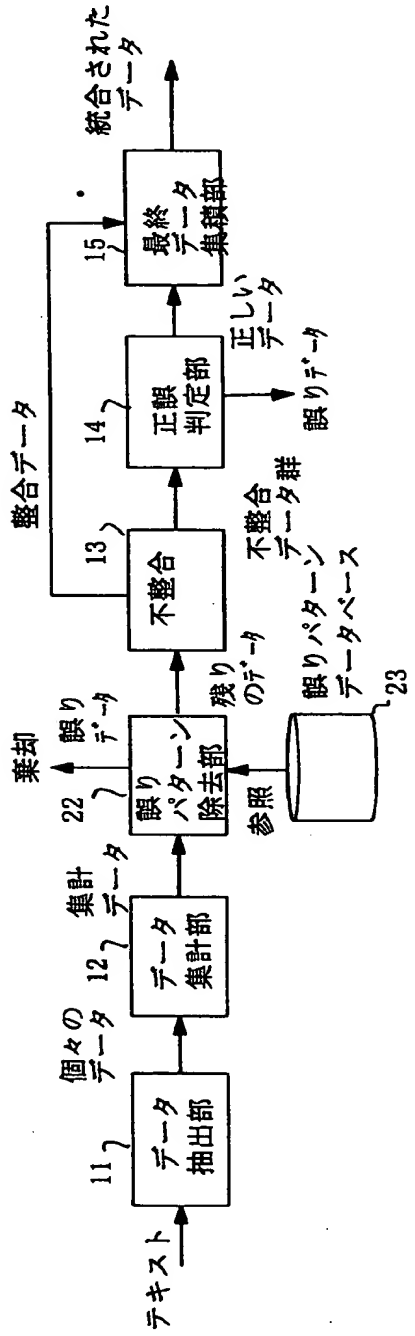

【図１７】

第４の実施例における誤りパターンの判断例を示す図

（ａ）抽出データ例

A社	電話番号	０３－３５６－７０９８
B社	電話番号	１１９－０００３

（ｂ）誤りパターン例

属性名	正規表現	意味
電話番号	^〔^０〕〔０－９〕＋	０で始まらない数字

（ｃ）正誤判断例

データ			正誤
A社	電話番号	０３－３５６－７０９８	正
B社	電話番号	１１９－０００３	誤

【図１８】

本発明の第５の実施例を示す図

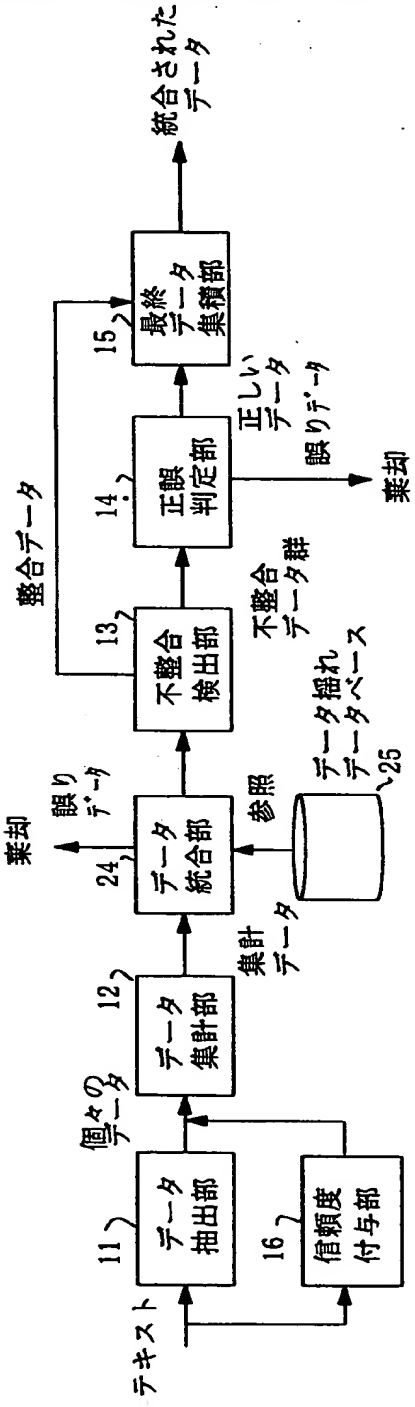

【図１９】

第５の実施例の処理例を示す図

（ａ）抽出データの例

対象事物	属性名	属性値	頻度
A社	代表者	山田一郎	２０件
A社	代表者	山田	２０件
A社	代表者	鈴木太郎	３０件

（ｂ）データ統合処理結果の例

対象事物	属性名	属性値	頻度
A社	代表者	山田一郎	４０件 （山田の２０件追加）
A社	代表者	鈴木太郎	３０件

（ｃ）正誤判断例

対象事物	属性名	属性値	頻度	正誤
A社	代表者	山田一郎	４０件	正
A社	代表者	鈴木太郎	３０件	誤

【図２０】

テキスト中の情報の抽出方法を説明する図

（ａ）対応表の例

〔表現形式〕　＊１の社長に＊２が決定

（ｂ）抽出データ

対象事物	属性名	属性値
＊１	代表者	＊２

（ｃ）処理例

〔入力テキスト〕 Ａ社とＢ社の合弁によって設立されるＣ社の新社長に （＊１にマッチ） Ｄ氏が決定した。 （＊２にマッチ）

（ｄ）抽出されるデータ

対象事物	属性名	属性値
Ｃ社	代表者	Ｄ氏

【書類名】　　要約書

【要約】

【課題】　テキスト中の誤った記述や抽出処理の誤りに起因する抽出データ中の誤りやバラツキの誤り部分を排除して、適切なデータの集積を行なうこと。

【解決手段】　データ抽出部１により、対象とする事物、属性名、属性値の３つ組によって規定される事実データをテキストから抽出し、抽出された事実データについて、データ集計部２でテキスト全体にわたり同種のデータをまとめ、生起回数を集計する。不整合検出部３はデータ集計部２において集計されたデータ集合を走査して両立し得ない不整合データ群を検出し、正誤判定部４において、不整合データ群の中でどれが正しいデータであるかを判断する。最小データ集積部５は、正しいデータを集積して出力する。また、事実データをテキストから抽出する際にデータに信頼度を付与し、データに付与された信頼度を利用してデータ群中の各データの正誤の判断を行なうこともできる。

【選択図】　　図１

出　願　人　履　歴　情　報

識別番号　　〔０００００５２２３〕

１．変更年月日　　１９９６年　３月２６日
［変更理由］　住所変更
住　所　　神奈川県川崎市中原区上小田中４丁目１番１号
氏　名　　富士通株式会社